Федеральное государственное бюджетное образовательное учреждение
высшего образования «Российский химико-технологический университет
имени Д.И. Менделеева»

На правах рукописи

Чернухин Артём Валерьевич

Автоматизированная система прогнозирования технического состояния промышленного оборудования на базе методов искусственного интеллекта

2.3.3. Автоматизация и управление технологическими процессами и производствами

АВТОРЕФЕРАТ

диссертации на соискание ученой степени

кандидата технических наук

Москва – 2025

Работа выполнена на кафедре кибернетики химико-технологических процессов федерального государственного бюджетного образовательного учреждения высшего образования «Российский химико-технологический университет имени Д. И. Менделеева».

Научный руководитель:	**Савицкая Татьяна Вадимовна** доктор технических наук, профессор профессор кафедры кибернетики химико-технологических процессов ФГБОУ ВО «Российский химико-технологический университет имени Д. И. Менделеева»
Официальные оппоненты:	**Матвеев Юрий Николаевич** доктор технических наук, профессор профессор кафедры «Электронные вычислительные машины» ФГБОУ ВО «Тверской государственный технический университет»
	Обухов Артём Дмитриевич доктор технических наук, доцент ведущий научный сотрудник НИЛ «Лаборатория медицинских VR тренажерных систем для обучения, диагностики и реабилитации» управления фундаментальных и прикладных исследований ФГБОУ ВО «Тамбовский государственный технический университет»
Ведущая организация	**ФГАОУ ВО «Московский политехнический университет»**

Защита состоится «30» июня 2025 г. в 11:00 на заседании диссертационного Совета РХТУ.2.6.09 федерального государственного бюджетного образовательного учреждения высшего образования «Российский химико-технологический университет имени Д.И. Менделеева» (125047, Миусская пл., д. 9, ауд. 443, конференц-зал).

С диссертацией можно ознакомиться в Информационно-библиотечном центре и на официальном сайте https://www.muctr.ru федерального государственного бюджетного образовательного учреждения высшего образования «Российский химико-технологический университет имени Д. И. Менделеева».

Автореферат разослан «__ » _____2025 г.

Ученый секретарь диссертационного
совета РХТУ.2.6.09
Кандидат технических наук, доцент В. А. Василенко

ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

Актуальность темы исследования. Разработка автоматизированной системы прогнозирования технического состояния промышленного оборудования на основе методов искусственного интеллекта (ИИ) приобрела особую актуальность в последние годы в связи с рядом факторов.

Во-первых, непрерывно возрастающая сложность устройства современного промышленного оборудования, характеризующаяся растущим числом датчиков, исполнительных механизмов и систем управления, делает классический мониторинг и анализ технического состояния оборудования в реальном времени все более трудоемким, а в некоторых случаях и невозможным без использования решений на основе методов ИИ. Помимо этого, внедрение Индустрии 4.0 и глобальная цифровизация привели к значительному увеличению объема данных, генерируемых промышленным оборудованием. Следовательно, автоматизированные системы прогнозирования на основе ИИ могут обработать и проанализировать эти данные для выявления паттернов, трендов и аномалий, что позволяет заблаговременно проводить профилактическое обслуживание и уменьшать простои. Также, разработка автоматизированной системы прогнозирования позволит промышленности снизить затраты, связанные с обслуживанием, ремонтом и заменой оборудования. Компании, которые внедряют системы прогнозирования на основе ИИ, могут получить конкурентное преимущество, повышая общую эффективность и производительность, промышленную и экологическую безопасность, идентифицируя потенциальные отказы оборудования, которые могут привести к авариям или экологическим катастрофам. Наконец, немаловажным фактором актуальности данной задачи является то, что непредвиденные неисправности и отказы оборудования на опасных производственных объектах могут привести к серьезным травмам или даже человеческим жертвам. Таким образом, данная задача является крайне актуальной и массовое внедрение подобных систем на предприятиях приведет к значительному росту промышленного потенциала государства в целом.

Степень разработанности темы. Теоретические основы математических методов, компьютерного моделирования и оптимизация режимов сложных технологических систем разработаны в трудах: академика АН СССР и РАН РФ Кафарова В. В., академика РАН РФ Мешалкина В. П., профессоров Егорова А. Ф., Савицкой Т. В.

Существенный вклад в разработку и изучение методов интеллектуальной поддержки принятия решений при управлении техническим состоянием оборудования внесли Н.И. Уткин, А.А. Жданович, А.Н. Бажинов, И.Г. Овчинникова, В.Л. Чугреев, С.М. Боровников, М.С. Мангалова, М. Липатов, Д.Луи (J. Lui), П.Баралди (P. Baraldi), С.Лиу (S. Liu), З. Ванг (Z. Wang), А. Вув (A. Wuw). Работы по надёжности химико-технологических систем Б.В. Палюха, М.Н. Краснянского, Д.Ю. Муромцева, В. С. Шубина, Ю. А. Рюмина внесли большой вклад в развитие направления.

Широко известны работы в области совершенствования методов диагностики и управления техническим состоянием сложной техники на основе технологий нейронных сетей следующих авторов: С.В. Жернаков, А.М. Пашаев, А.Г. Кучер, П.И. Раков, Г.С. Бабу

(G.S. Babu), К. Джанг (X. Zhang), К. Ли (Xiang Li), Ж. Ли (Zhe Li), Р. Хуанг (R. Huang).

Отметим разработки коммерческих компаний General Electrics, Siemens, Pratt&Whitney, ЗАО РОТЕК, NASA, детальные результаты исследований которых не обнародованы, так как являются основанием для конкурентного преимущества.

Наличие теоретических и практических работ российских и зарубежных ученых и исследователей подтверждает актуальность темы и характеризует определенную степень ее разработанности. Тем не менее, недостаточная научная проработанность эффективных методов, моделей и алгоритмов прогнозирования технического состояния и оценки остаточного ресурса оборудования на базе методов искусственного интеллекта определяет необходимость дополнительных исследований.

В качестве объекта исследования выступает эксгаустер – промышленное оборудование, работающее в непрерывном режиме, часть агломерационной машины, представляет собой вентилятор (насос), основным назначением которого является удаление дымовых газов, паров и других вредных примесей.

Предметом исследования является автоматизированная система прогнозирования технического состояния промышленного оборудования.

Цель и задачи исследования. Цель исследования – разработка автоматизированной системы прогнозирования технического состояния промышленного оборудования на базе методов искусственного интеллекта.

Для достижения цели поставлены следующие задачи:

1. Проанализировать отечественные и зарубежные аналоги.
2. Разработать новую гибкую функциональную структуру автоматизированной системы прогнозирования технического состояния промышленного оборудования.
3. Разработать модели прогнозирования на основе методов искусственного интеллекта, которые смогут предсказывать возможные неисправности и отказы промышленного оборудования. Для этого требуется провести обучение моделей на исторических данных о неисправностях, отказах и рабочем состоянии оборудования.
4. Провести анализ объекта технической диагностики и собрать набор данных с информацией о неисправностях и отказах промышленного оборудования за большой временной интервал с низкой долей неисправностей, провести обработку данных.
5. Реализовать функциональную структуру автоматизированной системы прогнозирования, в том числе разработать веб-сервис, реализующий возможности хранения и обработки данных в режиме реального времени, имеющий удобный интерфейс для работы конечных пользователей.
6. Внедрить в систему функциональные возможности переобучения моделей на больших объемах непрерывно поступающих актуальных данных в автоматическом режиме без привлечения разработчиков.
7. Провести всестороннее тестирование работы системы в приближенных к реальности условиям.

Научная новизна. В процессе выполнения диссертации впервые были получены новые научные результаты:

1. Разработана новая функциональная структура автоматизированной системы

прогнозирования технического состояния промышленного оборудования, включающая в себя подсистемы импорта данных, хранения и обработки данных, прогнозирования, отображения данных и уникальную подсистему управления моделями, позволяющую дообучать модели с учетом динамически изменяющихся условий производственного процесса.

2. Предложен комплексный подход к прогнозированию технического состояния промышленного оборудования, заключающийся в постановке задач прогнозирования неисправностей и отказов, а также оценке остаточного срока службы оборудования и научно обоснована возможность реализации сформулированных постановок задач с использованием методов искусственного интеллекта

3. Предложен и реализован новый метод анализа и обработки данных о неисправностях промышленного оборудования, учитывающий специфику использования в автоматизированной системе прогнозирования, заключающуюся в предобработке данных в режиме реального времени с высокой скоростью и точностью с учетом их физической природы.

4. Предложен новый алгоритм диагностирования технических систем с использованием уникального ансамблевого подхода, на основе которого разработаны и обучены новые модели прогнозирования неисправностей и отказов промышленного оборудования с высокими метриками точности.

5. Предложен и реализован новый алгоритм прогнозирования остаточного срока службы оборудования, основанный на современных архитектурах нейронных сетей, показавший высокие метрики точности для горизонта прогнозирования, равного одному месяцу.

6. Предложен и апробирован новый подход к комплексному тестированию в приближенных к реальной промышленной эксплуатации условиям, заключающийся в комплексной симуляции рабочей среды, нагрузочном тестировании на исторических данных и проверке интеграции с промышленными системами, показавший высокую эффективность работы системы в рамках задач автоматизации контроля технического состояния промышленного оборудования.

Теоретическая значимость заключается в развитии методов построения интеллектуальных систем автоматизированного прогнозирования неисправностей промышленного оборудования.

Практическая значимость заключается в том, что разработанная автоматизированная система прогнозирования представляет большой интерес для разработчиков комплексных автоматизированных систем управления производственным процессом, так как выполняет функции сбора, хранения и обработки большого объема информации о состоянии промышленного оборудования, с высокой точностью прогнозирует его неисправности в режиме реального времени, а также обладает гибкой функциональной структурой.

Система способна оперативно предоставлять лицам, принимающим решение доступ к прогнозам и рекомендациям по предотвращению неисправностей и отказов, основанным на большом массиве данных, который оператор не может эффективно обработать

самостоятельно. Это достигается в том числе за счет возможности переобучения моделей в автоматическом режиме без привлечения разработчиков на накапливающемся массиве данных.

Методы исследования. Решение поставленных в диссертации задач основано на использовании современных методов и теорий: модели разработаны на базе методов искусственного интеллекта, а также реализована гибкая функциональная структура системы, предполагающая автоматизацию процессов сбора и обработки большого массива данных о состоянии промышленного оборудования.

Положения, выносимые на защиту:

- математическая модель, основанная на «мягком голосовании» между алгоритмом логистической регрессии, методом опорных векторов и сверточной нейронной сетью, способная с высоким качеством решать задачу прогнозирования неисправностей промышленного оборудования;
- математическая модель, основанная на алгоритме изолирующего леса, используемого для поиска аномальных режимов работы, а также нейронной сети краткосрочной долговременной памяти LSTM (Long short-term memory) в качестве классификатора, способная с высоким качеством решать задачу прогнозирования отказов промышленного оборудования;
- автоматизированная система прогнозирования неисправностей и отказов промышленного оборудования, обладающая уникальной гибкой функциональной структурой и включающая подсистемы импорта, хранения и обработки данных, прогнозирования, управления моделями и отображения;
- результаты апробации автоматизированной системы на задачах, близких к реальным, подтверждающие высокую стабильность работы системы.

Степень достоверности полученных результатов обеспечивается применением апробированного математического аппарата, корректным использованием исходных данных, согласованностью полученных результатов с результатами работ других исследователей.

Апробация работы. Основные результаты диссертационной работы доложены на III Международной научно-практической конференции «Компьютерные приложения для управления и устойчивого развития производства и промышленности» (Душанбе, Таджикистан, 2023); Международной конференции «Scientific research of the SCO countries: synergy and integration: Proceedings of the International Conference» (Пекин, Китай, 2023 г.); Международном университетском научном Форуме «Practice Oriented Science: UAE - Russia - India» (Дубай, ОАЭ, 2024); Межвузовском международном конгрессе «Высшая школа: научные исследования» (Москва, 2024), Международном научном форуме «Научный диалог: теория и практика» (Москва, 2025). Получен акт о внедрении результатов диссертационной работы в рамках разработки комплексной автоматизированной системы управления производственным процессом "НостраСУ".

Публикации. По теме диссертационной работы опубликовано 9 работ, из них 3 статьи – в изданиях, рекомендованных ВАК России для публикации научных результатов на соискание ученой степени кандидата наук, на соискание ученой степени доктора наук по

специальности 2.3.3. Автоматизация и управление технологическими процессами и производствами и 2 работы в зарубежных изданиях, индексируемых в международной базе научного цитирования Scopus.

Личный вклад автора. В совместных публикациях результаты, связанные с разработкой и обучением моделей прогнозирования неисправностей и отказов, проектированием и программной реализацией автоматизированной системы прогнозирования технического состоянии промышленного оборудования и проведением комплексного тестирования работы системы получены автором лично.

Структура и объем диссертации. Диссертационная работа состоит из введения, четырех глав, заключения, списка литературы и приложений. Общий объем работы составляет 186 страницу. Работа иллюстрирована 65 рисунками, содержит 7 таблиц и 1 приложение. Список литературы включает в себя 177 наименований.

ОСНОВНОЕ СОДЕРЖАНИЕ РАБОТЫ

Во введении обоснована актуальность темы диссертации, определены цель, задачи, объект и предмет исследования. Показана научная новизна работы, её теоретическая и практическая значимость. Представлены положения, выносимые на защиту, сведения об апробации результатов работы.

В первой главе «Анализ современного состояния научных исследований в области прогнозирования технического состояния промышленного оборудования» рассмотрена задача разработки системы прогнозирования технического состояния промышленного оборудования, остающаяся актуальной в России и мире на протяжении многих лет, что обусловлено несколькими факторами.

Во-первых, неисправности и отказы промышленного оборудования могут приводить к значительным финансовым потерям для предприятий. Они могут быть связаны с необходимостью проведения ремонтных работ, заменой комплектующих или даже приостановкой производственного процесса. Прогнозирование технического состояния оборудования позволяет предпринять меры по предотвращению возникновения отказов заблаговременно, за счет чего будут значительно снижены риски экономических убытков. Во-вторых, непредвиденные неисправности и отказы оборудования на опасных производственных объектах могут привести к аварии, серьезным травмам или даже человеческим жертвам. В-третьих, разработка системы прогнозирования технического состояния оборудования помогает предприятиям планировать ремонтные работы и обслуживание в наиболее подходящее время. Это позволяет не только снизить затраты на ремонт и замену комплектующих, но и увеличить эффективность работы оборудования. Кроме того, планирование ремонтных работ позволяет избежать неожиданной остановки производственного процесса, что способствует сохранению рабочих мест и стабильности работы предприятия. Наконец, неисправные или неэффективно работающие устройства потребляют больше энергии, что ведет к излишним расходам энергоресурсов и увеличению негативного воздействия на окружающую среду. Прогнозирование отказов и своевременное обслуживание оборудования помогает снизить потребление энергии и улучшить экологическую эффективность производства.

В последние годы возникли новые условия в постановке задачи разработки системы прогнозирования технического состояния промышленного оборудования. Многие промышленные компании, начиная с 2017 года, с помощью технологий Big Data начали хранить большие массивы данных о состоянии оборудования, которые в будущем предполагалось использовать для обучения моделей прогнозирования. На этом базисе были построены, например, решения Infotech Industry от отечественной компании Infotech Group (Инфотех Груп) и SmartSignal от General Electric. У данных решений есть целый ряд недостатков: использование устаревших моделей машинного обучения, невозможность дообучения моделей заказчиком (актуально для компаний с штатом Data Engineers), сложность интеграции в текущую инфраструктуру компании.

Во второй главе «Разработка функциональной структуры и математических моделей автоматизированной системы прогнозирования технического состояния промышленного оборудования» описано проектирование функциональной структуры и разработка моделей для прогнозирования неисправностей и отказов промышленного оборудования. Общий вид предлагаемой функциональной структуры системы представлен на рис. 1.

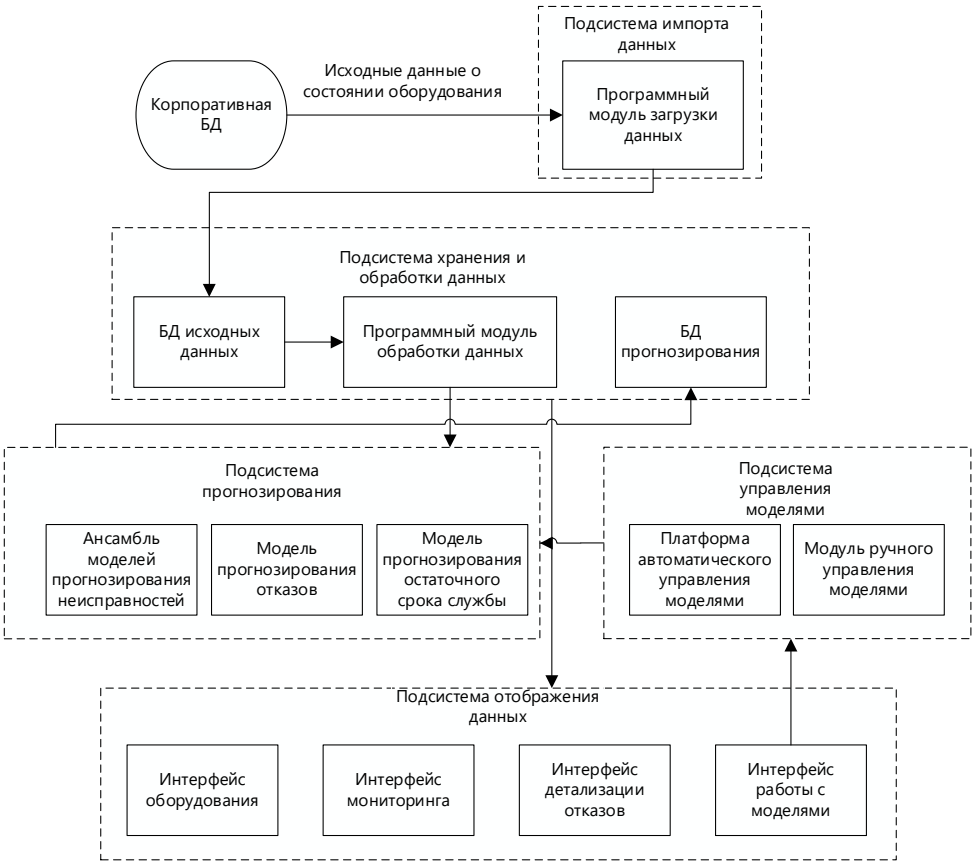

Рис. 1. Функциональная структура системы прогнозирования технического состояния промышленного оборудования.

На первом этапе исходные массивы данных подсистемой импорта загружаются в подсистему хранения, где происходит их предобработка. Далее предобработанные данные отправляются в подсистему прогнозирования, в которой реализованы модели, предсказывающие неисправности и отказы промышленного оборудования. Запуски процессов в этой подсистеме осуществляются автоматически через подсистему управления

моделями, в том числе и дообучение моделей на непрерывно поступающих актуальных данных. Результаты работы моделей также записываются в подсистему хранения. Взаимодействие с моделями может осуществляться в ручном режиме через подсистему отображения данных, в которой отображаются как результаты работы моделей, так и исходные данные, которые могут использовать конечным пользователем для мониторинга в режиме реального времени. Далее будет подробно рассмотрена разработка ключевой подсистемы в рамках данной структуры – подсистемы прогнозирования.

Методы классического машинного обучения (МО) широко применяются в диагностике и прогнозировании неисправностей оборудования из-за своей хорошей интерпретируемости, низких требований к вычислительным ресурсам и разнообразных подходов к анализу данных. Однако, в сравнении с нейросетевыми алгоритмами, классические методы проявляют ограничения в идентификации сложных взаимосвязей между показателями датчиков и состоянием оборудования. Нейросетевые алгоритмы предлагают больший потенциал, но в большинстве исследований они применяются только для диагностики одного технического места (аналог термина компонент технической системы, используемый на многих промышленных предприятиях), что затрудняет их масштабирование. Кроме того, для обучения и тестирования этих алгоритмов используются наборы данных с большим количеством примеров неисправностей, что сложно обеспечить в условиях реального производства. В связи с этим, система прогнозирования, работающая в режиме реального времени, должна использовать как методы классического машинного обучения, так и нейросетевые алгоритмы, чтобы компенсировать их недостатки, связанные с переобучением при ограниченных данных о неисправностях. В предлагаемом подходе заключается научная новизна исследования, так как в предыдущих работах по данной тематике использовался только один класс методов.

Рассмотрим работу алгоритма прогнозирования неисправностей. Постановка задачи формулируется следующим образом:

в наборе данных D имеется n единиц однотипного оборудования, каждое из которых анализируется одинаковым количеством датчиков ($s(D_1) = s(D_n)$) и содержит фиксированный набор совпадающих технических мест ($p(D_1) = p(D_n)$). При этом продолжительность эксплуатации, причины и динамика развития деградаций для каждой единицы оборудования и для каждого технического места могут различаться. Требуется по информации, заданной множеством D построить алгоритм F:

$$\forall\, p \in Di, S_t(D_i) \xrightarrow{F} C_p = \{C_{Norm},\, C_{Faul}\} \tag{1}$$

который позволяет по входящим значениям датчиков за определенный временной интервал (S_t) единицы оборудования (D_i) отнести состояние каждого технического места (p) к одному из возможных классов работоспособности (C_p): нормальное состояние (объединяет исправное и работоспособное состояния) (C_{Norm}) и неисправное состояние (объединяет неисправное и критическое состояния) (C_{Faul}).

В связи со сложной взаимосвязью между показаниями датчиков и состоянием эксгаустера было принято решение о создании модели прогнозирования, основанной на «мягком голосовании» между несколькими алгоритмами, имеющими различные подходы к классификации.

Суть данного ансамблевого метода заключается в подборе к каждому из предсказательных алгоритмов весов, отражающих значимость прогноза. Подбор весов осуществлялся с использованием метода градиентного бустинга. Для каждого объекта рассчитывается вероятность принадлежности к классу по следующей формуле:

$$P_1 = w_a * p_{a1} + w_b * p_{b1} + w_c * p_{c1}, \quad (2)$$

где P_1 – итоговая вероятность принадлежности объекта к классу 1 (неисправность), p_{a1}, p_{b1}, p_{c1} – вероятности принадлежности объекта к классу 1, предсказанные тремя отдельными алгоритмами, w_a, w_b, w_c – веса, присваиваемые прогнозам отдельных алгоритмов.

Для улучшения точности прогнозирования моделей в ансамбле будет использоваться "мягкое голосование" (SoftVoting). Модель должна быть обучена на данных с долей неисправной работы менее 15% для каждого технического места, и прогнозирование возникновения неисправностей для всех ключевых технических мест должно осуществляться одновременно. В работах по прогнозированию отказов обучают чаще всего следующие модели: catboost и xgboost (основаны на градиентном бустинге), реккурентные и сверточные нейронные сети. Но эти подходы плохо показывают себя при тестировании на данных, полученных с производства, так как возникает ранее упомянутая проблема – обучение производится на наборах данных, в которых присутствовало большое количество примеров отказов. Потому для «мягкого голосования» было принято решение использовать следующие подходы: сверточную нейронную сеть, логистическую регрессию и метод опорных векторов. Выбор этих методов обусловлен низкой корреляцией их предсказаний друг с другом (менее 0,6) с относительно высоким качеством предсказания для большей части анализируемых технических мест (значение индекса Жаккара выше 0,5).

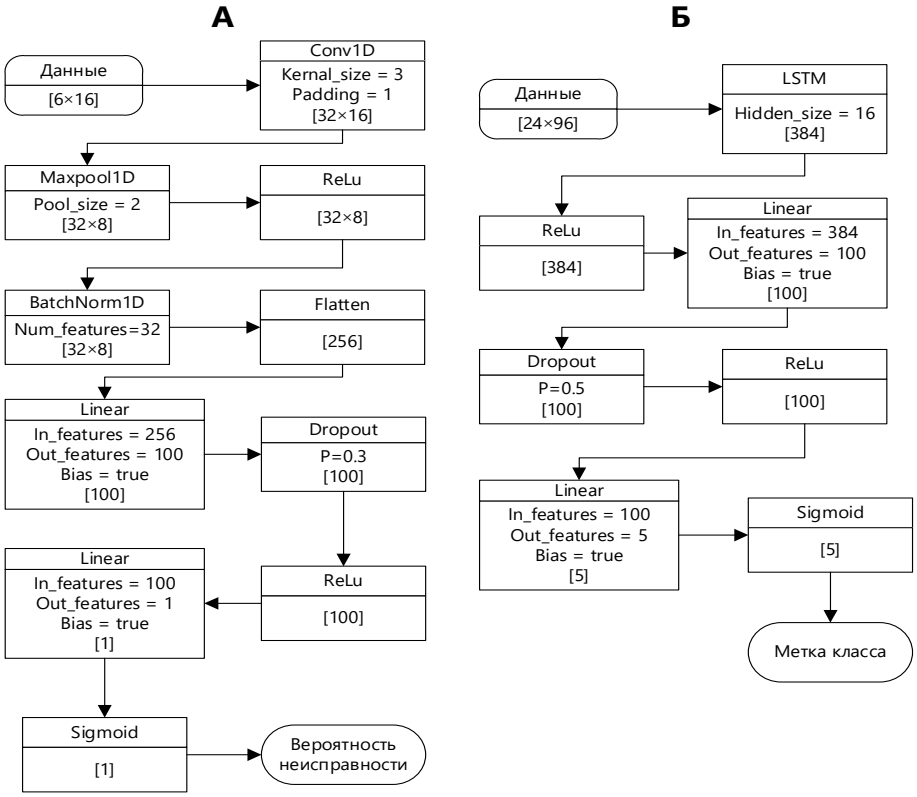

Рис. 2. Структура нейронных сетей системы прогнозирования технического состояния промышленного оборудования. А – идентификатор аномального режима работы оборудования, Б – классификатор аномалий по техническим местам.

Архитектура сверточной нейронной сети (рис. 2А) подбиралась, основываясь на принципе получения лучшей обобщающей способности при минимально возможной сложности модели. На первом этапе модель состояла из трех полносвязных слоёв, на вход для каждого часа подавался вектор размера 96, содержащий все рассчитанные признаки для каждого из 16 датчиков. При данной архитектуре достаточно рано наступало переобучение, даже при использовании различных методов регуляризации. Данное явление может быть связано со слишком большим признаковым пространством относительно размера обучающей выборки. В связи с этим были предприняты попытки уменьшения пространства признаков методом главных компонент, что замедлило переобучение, но при этом качество предсказания было достаточно низким. Следующим вариантом улучшения обобщения признаков было введение сверточного слоя перед полносвязными. Данный подход часто используется для извлечения закономерностей из признакового пространства как для одномерных, так и для двух- и трехмерных объектов. Замена первого полносвязного слоя на сверточный, с разбиением статистических показателей для каждого датчика на каналы, позволила как замедлить наступление переобучения, так и улучшить качество предсказания. Введение дополнительных сверточных слоёв значимых отличий в предсказание не внесло, следовательно, было принято решение оставить один сверточный и два полносвязных слоя.

Итоговая нейронная сеть (рис. 2А) содержит базовые слои, в которых происходит подбор весов:

сверточный слой (Conv1D) — выполняет функцию обобщения признаков в каналах, а также выявления значимых паттернов с увеличением числа каналов с 6 до 32. В качестве каналов используются статистические характеристики, рассчитанные для показателей каждого из 16 датчиков, в частности: среднее, медиана, максимальное и минимальное значения за час, а также разность между средним и медианой за час и за месяц. В связи с размером входного тензора, выбран размер ядра свертки (kernel size), равный 3. После сверточного слоя располагается слой подвыборки по максимальному значению (MaxPooling), который уменьшает в два раза размер тензора. В качестве функции активации использовалась выпрямленная линейная функция активации (ReLu);

два полносвязных слоя (Linear), с уменьшением количества каналов (100, 1). Для первого слоя использовалась функция активации ReLu. В последнем слое непосредственно и происходит предсказание наличия неисправности, и используется сигмоидная функция активации (Sigmoid), которая выводит вероятность принадлежности объекта к классу 1 (наличие неисправности).

Таким образом на вход алгоритм принимает 4D тензор размера 6x16, на выходе получаем одно число, отражающее вероятность наличия неисправности за час, который описывается входным тензором.

Метрикой качества выступает индекс Жаккара, рассчитанный по формуле:

$$J = \frac{TP}{TP + FP + FN}, \tag{3}$$

где J – индекс Жаккара, TP – истинно положительные значения из матрицы путаницы, FP – ложно положительные, FN – ложно отрицательные. Выбор данной метрики обусловлен

более объективной работой с наборами данных, содержащими низкую долю одного из классов.

Далее рассмотрим работу алгоритма прогнозирования отказов. Постановка задачи формулируется следующим образом: множество единиц оборудования и пространство признаков совпадают с данными, используемыми в предыдущей задаче. Однако изменения претерпели целевые метки состояния оборудования. Так, формулируется задача: по информации, заданной множеством D построить алгоритм F:

$$\forall\, p \in Di, S_t(D_i) \xrightarrow{F} C_p = \{C_{NotCr},\, C_{Cr}\} \tag{4}$$

который позволяет по входящим значениям датчиков за определенный временной интервал (S_t) единицы оборудования (D_i) отнести состояние каждого технического места (p) к одному из возможных классов работоспособности (C_p): некритическое (объединяет исправное, работоспособное и неисправное состояния) ($C_{NotCrit}$) и критическое состояние (C_{Crit}).

Изолирующий лес является одним из наиболее производительных методов поиска аномалий. Суть его работы заключается в изоляции наиболее отличающихся точек от нормальных с помощью ансамбля бинарных деревьев решений. В связи с тем, что аномальные точки достаточно сильно будут отличаться от остальных, они достаточно быстро будут отнесены деревом решений в отдельную ветвь.

Нейронная сеть долгосрочной кратковременной памяти LSTM (Long short-term memory) является одним из наиболее оптимальных методов работы с временными рядами, к которым относятся используемые данные. Суть метода заключается в анализе всей последовательности данных, с сохранением как особенностей отдельных интервалов, так и состояния всего периода.

В связи с необходимостью учета динамических изменений показаний датчиков относительно общего состояния за временной период было принято решение построения классификатора с использованием рекуррентных слоев (рис. 2Б). Изначальная структурв состояла из одного рекуррентного слоя, в качестве которого тестировались RNN (Recurrent neural network - Рекуррентные нейронные сети), LSTM и GRU (Gated Recurrent Unit - Закрытый рекуррентный блок) и двух последующих полносвязных. На первом этапе осуществлялся подбор временного интервала, единовременно подающегося на вход модели (12, 24, 48 и 72 часа). Наиболее высокое качество предсказания на валидационной выборке наблюдалось при использовании LSTM слоя и 24-часового интервала для входа. Введение дополнительного рекуррентного слоя значительно замедлило работу модели и привело к быстрому развитию переобучения. На следующем этапе эмпирически были подобраны параметры обучения, такие как размер скрытого состояния, значение отсева и L2-регуляризации.

Итоговая структура классификатора (рис. 2Б) содержит один LSTM-слой (размер скрытого состояния = 16, функция активации ReLu), два полносвязных слоя с сигмоидной функцией активации на выходном слое. Для обучения использовался оптимизатор AdamW (lr = 0,0001, weight_decay = 0,0001). В качестве функции потерь использовалась CrossEntropyLoss. В связи с ограниченным количеством данных и большой размерностью пространства признаков для борьбы с переобучением использовалась регуляризация: метод

прореживания (Dropout) со значением отсева 0,5 и L2-регуляризация, задаваемая параметром weight_decay, которая штрафует модель за большие значения весов.

Метрикой качества выступает оценка F1:

$$F1-score=\frac{2TP}{2TP+FP+FN}, \tag{5}$$

где F1-score – оценка F1, TP – истинно положительные значения из матрицы путаницы, FP – ложно положительные, FN – ложно отрицательные. Выбор данной метрики обусловлен более объективной работой с несбалансированными наборами данных при решении задачи классификации.

Далее рассмотрим работу алгоритма прогнозирования остаточного срока службы. Постановка задачи формулируется следующим образом: по информации, заданной множеством D построить алгоритм F:

$$\forall\, p \in Di, S_t(D_i) \xrightarrow{F} RUL_t(p) \tag{6}$$

который позволяет по входящим значениям датчиков за определенный временной интервал (S_t) единицы оборудования (D_i) оценить для каждого технического места (p) остаточный временной ресурс (RUL_t).

В качестве предсказательного алгоритма была выбрана нейронная сеть LSTM. Этот выбор обусловлен рядом преимуществ данной архитектуры при работе с временными рядами и возможностью анализа не одной временной точки, а целого интервала с сохранением информации о его состоянии.

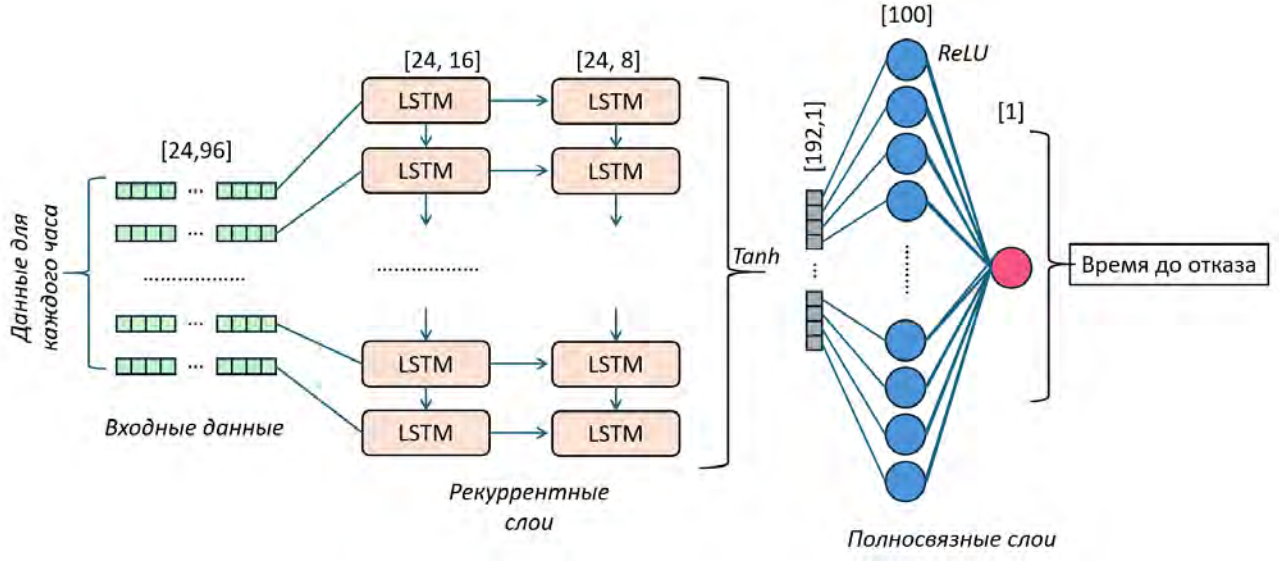

Рис. 3. Структура нейронной сети прогнозирования остаточного срока службы.

Так, на вход модели подавали данные показателей датчиков за 24 часа (размер массива 24x96), по итогу на выходе модель выводит показатель времени до отказа для последнего часа из последовательности (рис. 3). Структура предиктора включает в себя два LSTM-слоя, размер скрытого состояния которых равен 16 и 8 соответственно, и последующие два полносвязных слоя с размером 100 каналов и 1 соответственно.

Для проверки обученной модели на тестовой выборке были выбраны следующие метрики качества: RMSE и WRMSE, которые рассчитываются по следующим формулам:

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}, \quad (7)$$

$$WRMSE = \frac{1}{W}\sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}, \quad (8)$$

где n – количество точек, y_i – истинное значение, $\hat{y}_i$ – предсказанное значение, W -размер окна прогнозирования. Таким образом, RMSE отражает ошибку в абсолютных значениях (в нашем случае в часах), а WRMSE отражает отношение величины ошибки к размеру горизонта прогнозирования.

В третьей главе «Программная реализация функциональной структуры автоматизированной системы прогнозирования технического состояния эксгаустера агломерационной машины» описывается программная реализация структуры системы, которая представлена на рис. 1.

Для обучения моделей использовались данные, полученные от ПАО «Северсталь», а в качестве оборудования выступают эксгаустеры агломерационной машины – вентилятор, осуществляющий просос воздуха через слой шихты.

Первичные данные из корпоративных систем «Северстали» собираются и обрабатываются в подсистеме импорта данных, программный модуль которой реализован на высокоуровневом языке программирования Python, так как его гибкость и мощность позволяют создавать разнообразные модели, от машинного обучения до искусственного интеллекта. Одним из главных преимуществ использования Python для разработки моделей является его обширная система библиотек и фреймворков. Например, библиотеки такие как TensorFlow, PyTorch и Scikit-learn дают разработчикам мощные инструменты для создания и обучения сложных моделей. Благодаря этому, Python позволяет разрабатывать модели на высоком уровне, с минимальным количеством написанного кода.

В качестве базы данных для хранения исходных данных (подсистема сбора и хранения данных), получаемых из системы «Северстали», была выбрана ClickHouse – колоночная система управления базами данных (СУБД), разработанная компанией Яндекс. Она предназначена для аналитических запросов и обработки больших объемов данных в реальном времени. Основными преимуществами использования ClickHouse в данной работе являются ее высокая производительность, простая горизонтальная масштабируемость и минимизация задержки поступления данных. Дополнительно используется свободная объектно-реляционная система управления базами данных PostgreSQL для хранения результатов прогнозирования и дообучения моделей, так как колоночная БД для этих целей не подходит.

Для удобства работы с моделями (реализация подсистемы управления моделями) в проект была внедрена MLflow – открытая платформа для управления жизненным циклом машинного обучения. Она предоставляет набор инструментов и библиотек для упрощения и автоматизации процессов разработки, обучения и отладки моделей. MLflow поддерживает интеграцию с различными инструментами и библиотеками машинного обучения, включая TensorFlow, PyTorch, XGBoost и другие. Это обеспечивает универсальность и расширяемость платформы. Пользовательские функции и интерфейс (подсистема отображения данных) были реализованы на React – JavaScript-библиотеке с открытым исходным кодом для разработки

пользовательских интерфейсов, так как он обладает компонентной архитектурой и гибкой расширяемостью. Благодаря использованию программного обеспечения Docker, каждый из сервисов запускается в контейнере, а для управления приложениями в контейнерах применяется программное обеспечение Kubernetes. В итоге, функциональная структура системы предполагает удобное масштабирование системы при расширении перечня шаблонов прогнозирования для новых единиц оборудования.

Интерфейс системы, реализованный в соответствии с требованиями экспертов Северстали, состоит из четырех основных элементов (рис. 4)

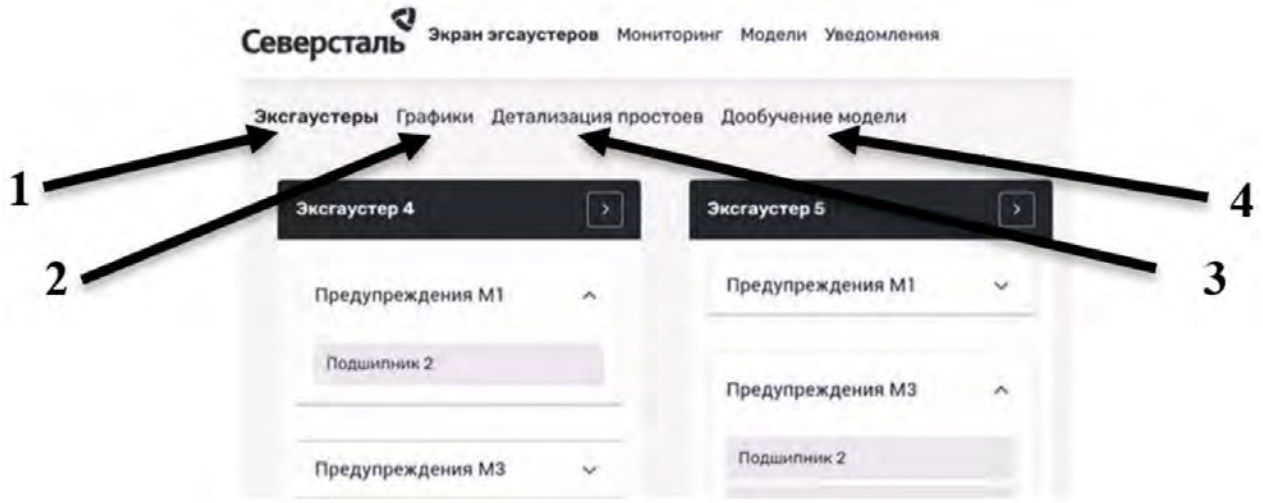

Рис. 4. Общий вид интерфейса системы.

1) «Эксгаустеры» – в режиме реального времени можно отслеживать предупреждения о спрогнозированных отказах типа М1 (внутреннее обозначение Северстали) и неисправностях типа М3, а также показания датчиков.
2) «Графики» – для более подробного анализа можно вывести исторические данные на гибко настраиваемый график.
3) «Детализация простоев» – вывод общей аналитики по простоям эксгаустеров и истории уведомлений о спрогнозированных неисправностях и отказах.
4) «Дообучение модели» – запуск дообучения модели и вывод метрик качества моделей.

Данные в систему поступают с шести эксгаустеров, в информационных ресурсах Северстали пронумерованных от 4 до 9. Оператору отображается детальная информация по простоям каждого эксгаустера за выбранный промежуток времени (рассчитанная как сумма простоев на каждом техническом месте конкретного эксгаустера), суммарная продолжительность отказов (М1) по техническим местам, время простоя каждого из типов технических мест по всем эксгаустерам, а также история уведомлений о предполагаемых отказах и простоях.

В системе предусмотрена возможность дообучения модели. Процесс обучения никак не влияет на текущую работоспособность системы. В случае необходимости, процесс можно остановить и посмотреть актуальные значения метрик качества (индекса Жаккара и F1-score) с указанием времени расчета. По итогам дообучения (если оно завершилось успешно и значения точности повысились) в таблице отобразятся новые значения метрик качества.

Можно сохранить отдельно отчет за указанный период времени, содержащий информацию обо всех потенциальных неисправностях и отказах. На графиках во вкладке

«Мониторинг» отображаются исторические данные по включенным технологическим узлам со всех датчиков для всех машин за выбранный промежуток времени.

Таким образом, были реализованы предложенные методы создания, эффективной организации и ведения специализированного информационного и программного обеспечения для удаленной диагностики и мониторинга технического состояния оборудования.

В четвертой главе «Тестирование разработанной автоматизированной системы прогнозирования технического состояния эксгаустера агломашины» описывается комплексное тестирование разработанной автоматизированной системы.

Предоставленный набор данных включает в себя показания шестнадцати датчиков для шести эксгаустеров, собранные за три года (с 01.01.2019 по 31.12.2021). Шаг фиксации измерений равен 10 секундам.

Датчики производят измерение следующих показателей оборудования: токи (А), температура технических мест (°С), давление масла (КПа), вибрации на опорах (мм/с). Количество и набор технических мест отличался для каждого из эксгаустеров (от 20 до 35). В исторических данных набор технических мест, проблемы в работе которых приводили к отказу оборудования, индивидуален для каждого из эксгаустеров. Перед обучением алгоритма проводилась предобработка показаний датчиков, необходимая для качественного обучения моделей и улучшения их обобщающей способности.

Во-первых, производилась очистка данных от выбросов. В частности, осуществлялось обнуление отрицательных (токи, температуры, давление, вибрации) и усреднение завышенных значений, так как они явно не отражают состояние оборудования и негативно влияют на обучение.

Следующим этапом подготовки данных является расчет статистических характеристик показаний датчиков за каждый час. Фиксация показаний изначально производилась с шагом в 10 секунд, что является избыточным и не удобным для дальнейшего обучения в связи с зашумленностью и большим объемом занимаемой памяти. Для каждого часового интервала рассчитывались такие характеристики как: среднее, медиана, максимальное и минимальное значения. Исходные данные были приведены к часовым интервалам (26280 строк для каждого эксгаустера) с увеличением количества признаков от 16 (количество датчиков) к 64 (статистические параметры для всех датчиков). В связи с различной природой и размерностью показаний датчиков, производилась их стандартизация. Оставшиеся пропущенные значения заполнялись путем интерполяции. Заключительным этапом обработки данных являлось добавление новых признаков, которые внесли информацию о различиях между состоянием оборудования за текущий час и состоянием за последнюю неделю. Для этого рассчитывалась разность между средними и медианными значениями за эти периоды.

С целью раннего обнаружения неисправной работы технических мест эксгаустеров производился подбор моделей прогнозирования и их гиперпараметров. В результате корреляционного анализа были отобраны следующие модели: сверточная нейронная сеть (CNN), метод опорных векторов (SVM) и логистическая регрессия (LR). Производилось как индивидуальное обучение для каждого метода, так и в составе ансамбля, реализуемого с

использованием операции «мягкого голосования» SoftVoting. Наилучшие значения метрики качества на тестовом наборе данных были получены для ансамблевого метода (табл. 1). Причем, для ряда технических мест удалось значительно улучшить точность предсказания относительно отдельных моделей, так для корпуса индекс Жаккарда улучшился на 0,17, для улиты и вибропреобразователя – на 0,1, для электроаппаратуры – на 0,08. Для этих же технических мест удалось достичь лучшего качества предсказания, что вероятно связано с более быстрым развитием неисправностей (электроаппаратура и вибропреобразователь) или с высоким отклонением показателей датчиков при нормальной и неисправной работе (корпус, улита, вибропреобразователь).

Прогнозирование для остальных технических мест происходит с более низкой точностью. Однако, это связано с выявлением режима неисправной работы до его идентификации сотрудниками, то есть алгоритм идентифицирует зарождение аномалий в работе оборудования, что может оказаться полезным для проведения профилактических работ и принятия превентивных мер.

Таблица 1. Результаты прогнозирования неисправностей на тестовой выборке.

Техническое место	**Индекс Жаккарда**			
	CNN	**LR**	**SVM**	**Voting**
Ротор	0,6	0,51	0,4	**0,63**
Корпус	0,5	0,47	*0,6*	**0,77**
Улита	0,71	*0,77*	0,53	**0,87**
Электродвигатель	0,7	0,65	0,63	**0,73**
Электроаппаратура	0,71	0,7	*0,79*	**0,87**
Вибропреобразователь	0,63	0,34	*0,68*	**0,78**
Подшипник опорный	0,54	0,3	0,34	**0,57**
Маслоохладитель	0,5	0,55	0,45	**0,57**

Во второй части работы производилось построение алгоритма, прогнозирующего развитие аномального режима работы эксгаустера, ведущего к отказу оборудования.

По итогу произведенного анализа случаев отказов эксгаустеров было выявлено, что развитие отказов в разных технических местах наиболее значимо отражается в показаниях определенного набора датчиков. Так, для ротора необходим мониторинг показателей температуры и вибрации на опоре, давления и температуры масла. Для электродвигателя – температура на опорах, а также токи ротора и статора, как и для электрооборудования. Для подшипника же актуально отслеживание только температуры и вибрации на опоре.

В технической документации по работе эксгаустеров агломашины описаны критические показания датчиков (температура, давление и т.д.), при которых происходит непосредственно отключение оборудования. Одними из наиболее нагруженных, и, в связи с этим, наиболее изученных компонентов эксгаустера в плане развития неисправностей являются подшипники опор ротора. Так как работа этих технических мест связана с постоянной ударной нагрузкой, их изнашивание происходит постепенно, и развитие неисправностей связано с плавным или скачкообразным увеличением вибрации на опорах.

Одной из основных проблем в диагностике отказов эксгаустеров является тот факт, что подавляющая часть данных содержит периоды нормальной работы, что делает невозможным применение только алгоритмов, основанных на обучении «с учителем», хотя они являются наиболее точными. В связи с этим на первом этапе предсказания происходит отбор потенциальных режимов аномальной работы с использованием изолирующего леса. Частота появления аномалий задавалась параметром contamination = 0,03, чего оказалось достаточно, чтобы все отказы в тренировочном наборе данных входили в спрогнозированные аномальные интервалы. Благодаря данному подходу удалось отсеять 97% данных и локализовать дальнейшую работу алгоритмов прогнозирования на потенциально аномальных режимах работы.

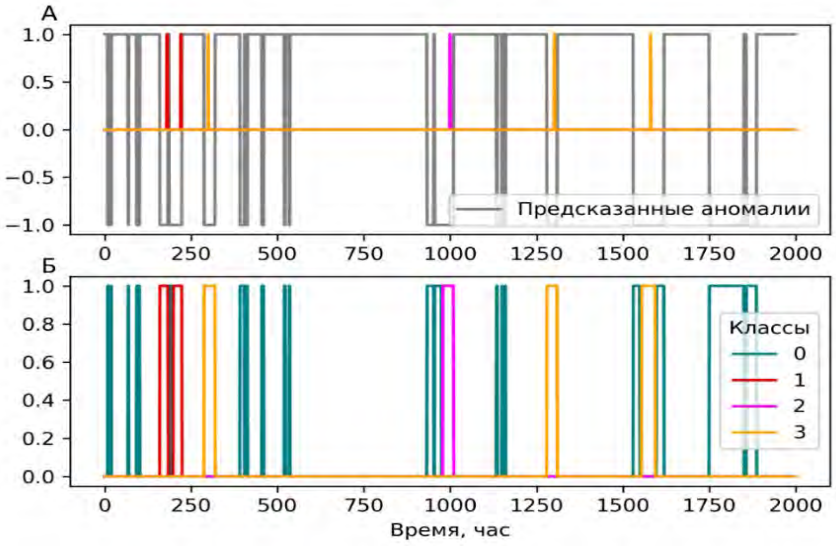

Рис.5. Результат прогнозирования отказов для одного из фрагментов тестового набора данных.

Был реализован двухэтапный алгоритм раннего прогнозирования отказов эксгаустера. После обучения производился анализ на тестовом наборе данных, содержащий определенный интервал работы для каждого из эксгаустеров. На первом этапе производился поиск аномальных режимов работы с помощью обученного изолирующего леса (рис. 5А), на втором – классификация выделенных аномалий нейронной сетью LSTM по техническим местам, ставшим причиной отказа, в случае его возникновения (1 – ротор, 2 – электродвигатель, 3 – подшипники), в противном случае интервал определялся как нормальный режим работы (класс 0) (рис. 5Б).

Из рис. 5А следует, что изолирующий лес успешно выделяет все периоды аномальной работы, повлекшие за собой неисправности, однако, при этом для него характерно достаточно много ложноположительных результатов. Можно предположить, что в эти периоды также развивается аномальная работа, однако в связи с ранним обнаружением или профилактическими работами, данные неисправности не приводят к отказам оборудования.

Далее отобранные аномальные интервалы классифицировались по техническим местам. В результате для тестового периода удалось верно определить технические места, в которых развивалась критическая неисправность (рис. 5Б).

В результате обучения классификатора на тестовом наборе данных удалось достичь среднего значения оценки F1, равной 0,74. Также для каждого технического места было

отдельно рассчитано значение метрики качества: ротор – 0,92; подшипники – 0,9; электродвигатель – 0,76; электроаппаратура – 0,38. Подобное распределение значений обусловлено факторами, повлекшими неисправности. Например, все отказы для ротора и подшипников были связаны с изменением в физических характеристиках, отклонения в которых развиваются продолжительное время (температуры, вибрации, давление). Для электродвигателя добавляются причины отказа, связанные с токами, аномальные режимы в которых развиваются крайне стремительно (от нескольких минут до нескольких часов), что не позволяет заранее диагностировать развитие серьезного дефекта с возможностью идентифицировать само состояние отказа оборудования с поправкой на несколько часов до него. Следовательно, для электроаппаратуры, качество прогнозирования оказалось самым низким из анализируемых технических мест.

Метрики качества предсказания RUL обученных моделей на тестовых выборках представлены в таблице 2.

Таблица 2. Результаты тестирования обученной модели при разных горизонтах прогнозирования.

Горизонт прогнозирования	Техническое место	RMSE, часы	WRMSE, %
Сутки (24 часа)	Ротор	**0.6**	2.5
	Электродвигатель	7.3	30.4
	Подшипники	1.0	4.2
	Электроаппаратура	12.4	51.6
Неделя (168 часов)	Ротор	3.8	**2.3**
	Электродвигатель	19.2	11.4
	Подшипники	6.1	3.6
	Электроаппаратура	77.5	46.1
Месяц (672 часа)	Ротор	36.1	5.4
	Электродвигатель	98.6	14.7
	Подшипники	23.4	3.5
	Электроаппаратура	111.7	16.7

Можно заметить, что наилучшее качество предсказания относительно горизонта прогнозирования характерно для ротора: WRMSE = 2.3% для прогнозирования на неделю вперед. При этом для данного технического места характерна и самая маленькая абсолютная ошибка: RMSE = 0.6 часа для горизонта равного суткам. Также достаточно высокое качество предсказания наблюдается для подшипников, при этом наилучшее соотношение соответствует предсказанию на месяц. Таким образом, RUL для подшипников при горизонте прогнозирования в месяц можно предсказать с ошибкой, равной примерно суткам, данное качество можно считать практически значимым даже при таком большом интервале предсказания. Получившиеся высокие значения метрик для этих технических мест, вероятно, обусловлены возможностью отображения неисправностей в них при анализе температур подшипников и вибраций, аномалии в которых начинают развиваться гораздо раньше возникновения отказа. По схожим причинам не удалось получить высокого качества прогноза для электродвигателя и электроаппаратуры. Таким образом, с использованием разработанных моделей можно проводить исследование работы эксгаустеров в режиме

реального времени, а результаты этих исследований применять для планирования работ по оптимальному техническому обслуживанию.

В рамках тестовой среды было проведено всестороннее тестирование работы автоматизированной системы. На первом этапе была симулирована интеграция с различными источниками данных, включая датчики температуры, давления и вибрации, установленные на эксгаустерах. Аутентификация пользователей была протестирована с использованием тестовых учетных записей, которые имели различные уровни доступа. Оценка скорости выполнения запросов подтвердила, что система справляется с нагрузкой, а время ответа на запросы не превышает 2 секунд. Также был инициирован сценарий, при котором модель должна была дообучиться на новых данных, накопленных за последние 3 месяца. После дообучения было проверено, что качество предсказаний улучшилось, и метрики стали выше. Система была протестирована на предмет отслеживания производительности моделей и уведомления пользователей о снижении качества предсказаний. Интерфейс, отображающий данные с эксгаустеров, был протестирован на предмет мгновенного обновления графиков и диаграмм при поступлении новых данных. Было проведено нагрузочное тестирование: для этого был создан сценарий, имитирующий поступление данных от 100 датчиков одновременно. Результаты показали, что время отклика на запросы не превышает 3 секунд, даже при максимальной нагрузке. Были добавлены дополнительные узлы в кластер, на котором работала система, и проверено, что производительность не ухудшается при увеличении числа обрабатываемых данных.

В дальнейшем планируется проведение интеграции разработанной системы в архитектуру АСУТП предприятия, благодаря чему у оператора появится возможность в автоматическом режиме заводить наряды на техническое обслуживание оборудования через систему технического обслуживания и ремонта, а также взаимодействовать с исполнительными механизмами для переключения режимов работы оборудования с целью продления его срока службы.

В приложении представлены протоколы тестирования.

ЗАКЛЮЧЕНИЕ

В результате выполненных исследований получены следующие основные научные и практические результаты:

1. Проведен анализ современного состояния исследований в области прогнозирования технического состояния промышленного оборудования, показавший высокую актуальность разработки автоматизированной системы прогнозирования технического состояния промышленного оборудования на базе методов искусственного интеллекта.
2. Разработана новая функциональная структура автоматизированной системы прогнозирования технического состояния промышленного оборудования, включающая в себя подсистемы импорта данных, хранения и обработки данных, прогнозирования, отображения данных и уникальную подсистему управления моделями, позволяющую дообучать модели с учетом динамически изменяющихся условий производственного процесса.

3. Разработан инновационный подход к анализу и обработке данных о состоянии промышленного оборудования, учитывающий особенности автоматизированных систем прогнозирования, заключающийся в обработке данных в режиме реального времени с высокой скоростью и точностью с учетом их физической природы.

4. Предложен алгоритм диагностики технических систем, основанный на ансамблевом подходе, который позволяет создавать и обучать высокоточные модели прогнозирования неисправностей и отказов промышленного оборудования.

5. Предложен и реализован новый алгоритм прогнозирования остаточного срока службы оборудования, основанный на современных архитектурах нейронных сетей, показавший высокие метрики точности для горизонта прогнозирования, равного одному месяцу.

6. Реализована функциональная структура автоматизированной системы, предоставляющей пользователю доступ к прогнозам и рекомендациям по предотвращению неисправностей и отказов, способной в автоматическом режиме без привлечения разработчиков обучаться на накапливающемся массиве данных.

7. Проведено тестирование автоматизированной системы прогнозирования технического состояния промышленного оборудования в приближенных к реальности условиях, подтвердившее высокую эффективность её использования для решения задач контроля технического состояния эксгаустера агломашины.

Таким образом, с использованием разработанной системы прогнозирования можно проводить исследование работы эксгаустеров в режиме реального времени, а результаты этих исследований применять для планирования работ по оптимальному техническому обслуживанию и ремонту.

В текущем виде разработанное программное обеспечение может использоваться на одном из промышленных предприятий и будет показывать свою эффективность при прогнозировании неисправностей технологических узлов эксгаустера. Так как архитектура системы и модели прогнозирования разработаны с учетом специфики работы с реальными промышленными данными и не привязаны к конкретному типу оборудования, решение может эффективно масштабироваться в комплексную систему прогнозирования предприятия. Для этого достаточно провести дообучение на новых данных с сохранением базовой архитектуры алгоритма и изменением только входного слоя нейронных сетей.

СПИСОК РАБОТ, ОПУБЛИКОВАННЫХ АВТОРОМ

1. Chernukhin A. V. Development of a model for predicting failures of high-tech production equipment based on machine learning algorithms / A. V. Chernukhin, E.A. Bogdanova, T.V. Savitskaya, A.M. Sverchkov, A.V. Dementienko // Third International Conference on Optics, Computer Applications, and Materials Science. – 2023. – № 11. – С. 1306515. (**Scopus**)

2. Чернухин А. В. Система предиктивной аналитики технического состояния эксгаустера агломашины с помощью методов искусственного интеллекта / А. В. Чернухин, Е. А. Богданова, Т. В. Савицкая, Д. Г. Кулаков, И. Р. Павлов // Искусственный интеллект и принятие решений. – 2024. – № 3. – С. 87-103. (**Scopus**)

3. Чернухин А. В. Построение модели предиктивной аналитики неисправностей

промышленного оборудования / А. В. Чернухин, Е.А. Богданова, Т. В. Савицкая // Программные продукты и системы. – 2024. – № 2. – С. 254-261. (**ВАК**)

4. Чернухин А. В. Разработка алгоритма прогнозирования остаточного ресурса эксгаустера агломашины, основанного на машинном обучении / А. В. Чернухин, Т. В. Савицкая // Научно-технический вестник Поволжья. – 2024. – № 4. – С. 185-190. (**ВАК**)

5. Чернухин А. В. Разработка модели прогнозирования отказов высокотехнологичного производственного оборудования на основе алгоритмов изолирующего леса и рекуррентной нейронной сети / А. В. Чернухин, Т. В. Савицкая // Высшая школа: научные исследования: Материалы Межвузовского международного конгресса, Москва. – 2024. – С. 116-120.

6. Chernukhin A. V. A new method for predicting industrial equipment failures using machine learning / A. V. Chernukhin, E. A. Bogdanova, T. V. Savitskaya // Scientific research of the SCO countries: synergy and integration: Proceedings of the International Conference, Beijing. – 2023. – P. 193-197.

7. Chernukhin A. V. Development of an algorithm for predicting breakdowns of high-tech production equipment based on algorithms of an insulating forest and a recurrent neural network / A. V. Chernukhin, T. V. Savitskaya // Practice Oriented Science: UAE - RUSSIA - INDIA: Proceedings of the International University Scientific Forum, UAE. – 2024. – P. 166-170.

8. Чернухин А. В. Прогнозирование остаточного срока службы промышленного оборудования с использованием методов искусственного интеллекта / А. В. Чернухин, Т. В. Савицкая // Сборник научных статей по итогам работы Международного научного форума Научный диалог: теория и практика, Москва. 2025. № 1. С. 154-160.

9. Чернухин А.В. Разработка многофункционального умного датчика информационной системы эвакуации с химического предприятия / А.В. Чернухин, Т.В. Савицкая // Успехи в химии и химической технологии. – 2023. – Т. 37, № 11 (273). – С. 135-137.